

能動学習型サポートベクタマシンを用いた 内容に基づく画像検索における分類器の再利用基準の改善

Improvement of criterion for reuse of classifiers in CBIR using support vector machine active learning

手川 真彰*
Masaaki Tekawa

服部 元信†
Motonobu Hattori

1 研究の背景

従来、デジタル画像の検索は人間の手によって作成された索引を利用して行われてきた。しかし、近年の技術革新による画像データの増加に伴い、人手による索引付けは困難になった。また、索引付けを行う人間の主観が検索結果に影響を及ぼしてしまう恐れがある。

このような問題をコンピュータに解決させることを目的とした画像検索システムの1つとして、内容に基づく画像検索 (CBIR:Content-Based Image Retrieval) がある。このシステムは、画像の情報を特徴ベクトルで表現し、画像間の類似度を比較することにより、類似した画像を検索するシステムである。

一般に、検索システムが高い検索精度を示すためには、ユーザの要求を正確に理解しなければならない。そのため、システムとユーザの間で情報のやりとりが必要となる。この方法の一つとして、Tongらは適合性フィードバック (RF:Relevance Feedback) に着目し、能動学習型サポートベクタマシン (SVM:Support Vector Machine) を用いたCBIRを提案した [1]。

このシステムでは、検索が終了すると学習された分類器を破棄していた。そこで中島は、学習された分類器を保存し、新たな検索の際に分類器を再利用する手法を提案した [2]。この手法を用いることにより、Tongらの検索性能を上回ることが示された。

本研究では、中島の提案した分類器の再利用システムを改良することを目的とし、分類器の選択をより正確に行うための選択基準を提案する。また、実験により従来の選択基準に対する提案法の有用性について確かめる。

2 内容に基づく画像検索

内容に基づく画像検索は、ユーザから入力された画像から「色」「形」「テクスチャ」などの視覚的特徴を抽出し、画像データベース内から類似した画像を検索結果としてユーザに提示するシステムである。このように、視覚的特徴が類似した画像を検索することは比較的容易に実現できる。既存のシステムとして、問い合わせ画像を用いたQBIC[3],SIMPLcity[4]などが代表的である。

一方で、ユーザが画像に含まれる意味的概念による検索を行う場合、画像の視覚的特徴から高次の意味的概念を導く必要がある。しかしながら、通常1枚の画像には様々な意味的概念が存在しており、ユーザの要求する具体的な内容を判断するのは困難である。そこで、多くの

CBIRシステムでは、ユーザの意図を理解するために、RFが用いられることが多い。

CBIRにおける一般的なRFは、システムから提示された検索結果の画像に対し、検索要求に一致しているかどうかの評価を行っていくものである。このようなやりとりを繰り返し行うことによって、ユーザの具体的な検索要求に対し、リアルタイムで学習していくことが可能となる。しかしながら、この方法はユーザに多大な手間を与えてしまうため、少ない回数でのRFによりユーザの意図を学習することが必要不可欠となる。

3 能動学習型SVMを用いたCBIR

3.1 能動学習型SVM

能動学習型SVMは、学習効率の良いデータのみを能動的に取得することにより、優れた分類器を効率的に生成する手法である。学習効率の良いデータとは、SVMの識別超平面付近に存在し、学習データではないものを指す。そのようなデータを優先的に学習していくことにより、理想的な識別超平面を迅速に決定することができる。

いま、学習を行ったSVMの識別超平面が、図1(左)に表されているとする。この分離超平面付近の未学習データを獲得し、学習データに追加することにより、図1(右)のような識別超平面が新たに決定される。以上が、能動学習型SVMの学習方法である。




図1: 能動学習型SVMによる学習方法

3.2 能動学習型SVMのCBIRへの適用

能動学習型SVMを用いる場合、どのようにして学習データを獲得するかが問題になる。そこでTongらは、CBIRシステムがユーザに提示する画像群をLabel Set (RFを受け取るために提示する画像群)、Return Set (検索結果として提示する画像群) の2つに分けることにより、能動学習型SVMを用いたCBIRを実現した [1]。

*山梨大学大学院医学工学総合教育部, 甲府市

†山梨大学大学院医学工学総合研究部, 甲府市

Label Set は SVM の学習データとなる。この2つの画像群を用いて画像検索を行うための手順は以下の通りである。

初期入力 ユーザは問い合わせとして、「正事例」の画像1枚、「負事例」の画像1枚をシステムに与える。この2枚の画像は Label Set に追加される。

SVM の学習 Label Set を用いて SVM の学習を行う。
Return Set の提示 SVM の識別超平面に対して、正事例側に遠い順から r 枚をユーザに提示する (図 2)。ユーザが望む検索結果が得られなかったとき、次の手順に進む。

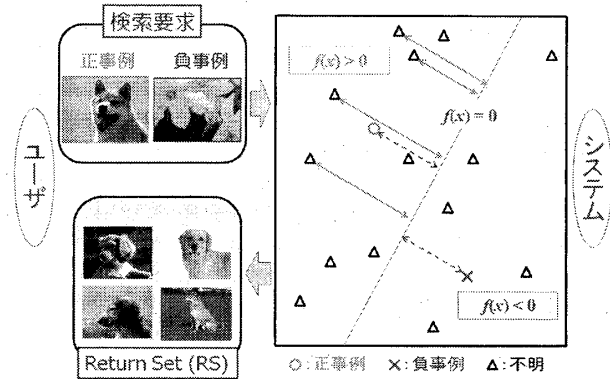


図 2: Return Set の提示 ($r = 4$)

Label Set の提示 まだラベル付けされていない画像を、識別超平面に近い順から l 枚取り出し、ユーザに対して提示する。

Relevance Feedback ユーザは Label Set に対して「正事例」、「負事例」のラベル付けを行い、システムにフィードバックする (図 3)。

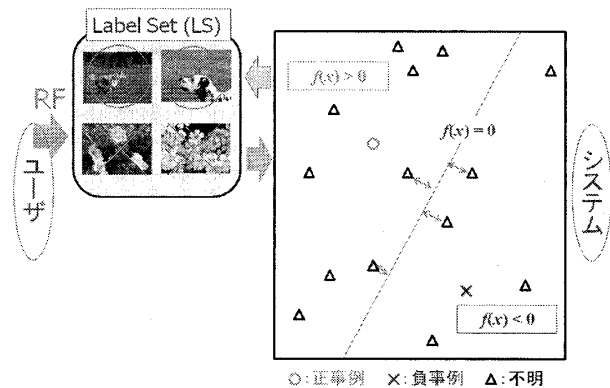


図 3: Label Set の提示 ($l = 4$) と、Label Set への Relevance Feedback.

SVM の学習 に戻る。

4 分類器の再利用

Tong らのシステムでは、検索の際に生成された分類器 (SVM) は、検索が終了した時点で破棄されていた。そこ

で中島は、この分類器を保存し、再利用する方法を提案した [2]。この手法により、迅速かつ高精度な検索結果を返すことが示された。また、再利用した分類器に対する追加学習により、さらに精度の高い分類器を生成することが可能となった。

4.1 再利用基準

いま、システムが複数の分類器を持つとし、 $f_k(x)$ を入力 x に対する分類器 k の出力とする。システムに対して、正事例の問い合わせ画像 x_R 、負事例の問い合わせ画像 x_{IR} が与えられたとき、再利用する分類器は入力 (x_R, x_{IR}) を正しく分類するもの、すなわち、

$$f_k(x_R) > 0 \text{ かつ } f_k(x_{IR}) < 0 \quad (1)$$

を出力する分類器とする。ここで、式 (1) を満たす分類器が複数存在するとき、

$$|f_k(x_R)| + |f_k(x_{IR})| \quad (2)$$

が、最大かつ閾値 $H (> 0)$ 以上となる分類器を再利用する (図 4)。

このように、入力データを正しく分類し、その分類の信頼度が最も高い分類器を再利用する。また、上記の条件を満たす分類器が存在しない場合、新たに分類器を作成する。この手法により、システムが早期の段階で適切な検索結果を提示することを可能とし、検索精度も向上することが示された。




図 4: 分類器の再利用を行うための基準。

5 分類器の再利用基準の改善

中島の研究では、正事例データと負事例データを識別する分類器のうち、それぞれのデータが識別超平面から最も離れている分類器を再利用した。しかし、ある検索要求に対する負事例データは、正事例データに比べ大量に存在するため、ユーザが選択する負事例データによって分類器の評価値が大きく変化してしまう。もし、ユーザの要求にそぐわない分類器を選択してしまうと、望ましくない検索結果になるだけでなく、その後の RF による学習によって、本来の分類器の検索性能が低下してしまう恐れがある。

そこで、分類器の選択の際に RF を適用し、分類器の選択をより正確に行う方法を提案する。この手順を以下に示す。

Step.1 ユーザから与えられた正事例データを元に、各分類器に以下の評価値を与え、上位 m 個の分類器を再利用の候補とする。

$$f_k(\mathbf{x}_R) \quad (3)$$

Step.2 候補となった分類器における正事例側のサポートベクトルを、分類器当たり l/m 個ずつランダムに獲得する。これらのデータを、それぞれの分類器の特徴を表す代表データとしてユーザに評価してもらい、ユーザが正事例と評価したデータを最も多く含む分類器を再利用する。ただし、該当する分類器において、ユーザが正事例と評価したデータ数が N 個未満の場合、再利用に値する分類器が存在しないと判断し、新たな分類器を作成する。

Step.3 該当する分類器が複数存在する場合、以下の評価値が最大なものを再利用する。

$$\sum_i f_k(\mathbf{x}_{Ri}) \quad (4)$$

ここで、 \mathbf{x}_{Ri} はユーザが正事例と評価したデータを表し、この式は、各分類器におけるそれらのデータに対する分類の信頼度を評価する。

また、正事例側のサポートベクトルは、過去の RF により学習されたデータであるため、その分類器の正事例という保証がある。このように、負事例データは学習データとしてのみ用い、分類器の候補選択の際には評価しない。そのため、負事例データへの依存を減らすことができる。

6 計算機実験

実験データとして、データクラフト社の著作権フリー画像集「フォトバイブル20000」より、2000枚(20クラス×100枚)の画像データと、5000枚(25クラス×200枚)の画像データを用いた。

また、1枚の画像に対し、色とテクスチャの特徴を抽出した。特徴ベクトルには、色特徴として Color Moment (9次元)、Color Histogramの問題点を改良した特徴量である Color Coherence Vector[5] (120次元)、テクスチャ特徴の、Haar Wavelet 変換 [6](18次元)を用いた。

SVM には非線形カーネルであるガウスクーネルを適用し、学習はソフトマージンを用いて行った [7]。全ての実験を通して、パラメータは統一して行った。

検索は、あらかじめ画像データに付加されたクラス情報を利用し、計算機による自動 RF を行った。一回の入力に対し5回の RF を行い、その適合率を調べた。従来法、提案法とも、1回の RF で獲得する Label Set の画像数 l は20枚とした。また、提案法では分類器候補の代表データへの評価 ($l=20$) も1回の RF とカウントした。なお提案法では、再利用する分類器の候補数 m は5つ、再利用のための閾値 N は2とした。

6.1 適合率の比較

2000枚の画像に対し、それぞれ1回ずつ検索及びSVMの学習を行った。この試行を10回行い、合計20,000回の検索における適合率の平均を図5に示す。

$$\text{適合率} = \frac{\text{検索結果中の正事例データ数}}{\text{検索結果} (r=20)}$$

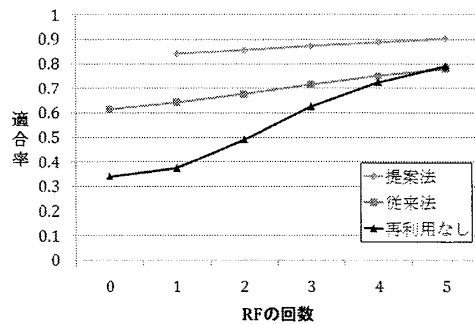


図5: 適合率の平均 (画像2000枚)

従来法では、ユーザの検索画像の入力に対し、その情報のみで再利用分類器を決定するため、RFを行わずに Return Set を返すことができる。一方、提案法では、ユーザの入力に対し、まず Label Set が返されるため、1度 RF を行わないと検索結果は返されないため、このようなグラフになる。実験結果から、全ての画像群において、提案法は従来法の適合率を上回っていることが分かる。また、初期の適合率が向上していることから、適切な分類器の選択が行われているといえる。

5000枚の画像に対しても同様の実験を行い、合計50,000回の検索における適合率の平均を図6に示す。




図6: 適合率の平均 (画像5000枚)

これらの結果から、画像数が増える、どの手法においても全体的な適合率が低下していく結果が示された。これは、クラス中の画像数の増加や、クラス数の増加によって、SVMにおけるパターン分離が難しくなったためだと考えられる。

6.2 学習時間

学習時間について、従来法との比較実験を行った。結果を図7-8に示す。

提案法では、従来法に比べ全体的な学習時間が短くなっていることが分かる。これは、個々の分類器に対する適切な追加学習によって分離精度が向上し、能動学習による識別超平面の更新量が減少するためだと考えられる。

また、提案法で1回目のRFに関する学習時間が少ないのは、ユーザから得られた学習データに対し、高い識別




図 7: 学習時間の平均 (2000 枚)




図 8: 学習時間の平均 (5000 枚)

率をもつ分類器を再利用しているため、それらのデータに対する学習の必要がほとんどないためと考えられる。

6.3 探索時間

計算機実験による分類器の探索時間の比較を行った。結果を表 1 に示す。提案法については、分類器候補の代表データに対し、RF を行う時間を省いている。

表 1: 探索時間の平均と最大 (Sec)

画像数	従来法		提案法	
	平均値	最大値	平均値	最大値
2000 枚	0.05	0.11	0.06	0.13
5000 枚	0.16	1.06	0.18	1.26

この結果から、従来法に比べ、提案法の探索時間が僅かに長くなることが分かった。しかしながら、実用上ほとんど問題にならない程度の差であった。

6.4 再利用率

それぞれの実験において生成された分類器数、再利用率について、表 2 に示す。

$$\text{再利用率} = \frac{\text{検索回数} - \text{分類器数}}{\text{検索回数}}$$

この結果から、提案法では生成された分類器数が減少し、再利用率が向上したことが分かる。つまり、個々の分類器に対する学習効率が上がったといえる。

表 2: 分類器数及び再利用率

画像数	従来法		提案法	
	分類器数	再利用率	分類器数	再利用率
2000 枚	390.4	0.804	130.0	0.935
5000 枚	1059.6	0.788	694.4	0.897

7. 結論

本研究では、能動学習型 SVM を用いた CBIR において、再利用する分類器の選択基準を改善することを目的とした。新たなアプローチとして、分類器選択の際に RF を行うことを提案した。また、負事例データに対する過度な依存を避けるため、分類器の評価基準を改善した。計算機実験において、提案法と従来法との検索精度の比較を行った結果、検索精度の向上を確認した。また、分類器の再利用率の向上により、生成される分類器を減らすことができた。

実際の検索システムの利用シーンでは、本実験のクラスより、さらに大規模で複雑な検索要求が存在すると予想される。しかしながら、システムの学習効率の向上による検索精度を比較するには、本実験のクラス数でも十分だと思われる。よって本実験において、提案法の有用性を確認することができた。

参考文献

- [1] S. Tong, E. Chang, "Support vector machine active learning for image retrieval," Proceedings of ACM International Multimedia Conference, pp.107-118, 2001.
- [2] 中島 聖志, 服部 元信, "能動学習型サポートベクターマシンを用いた内容に基づく画像検索における分類器の再利用," 情報処理学会第 70 回全国大会講演論文集, 1R-5, 1, pp.477-478, 2008.
- [3] W. Niblack, R. Barber, W. Equitz, M. Flickner, E. Glasman, D. Petkovic, P. Yanker, C. Faloutsos and G. Taubin, "Quering images by content using color, texture, and shape," In Proceedings of the SPIE Conference on Storage and Retrieval for Image and Video Databases, 2-3 February '93, San Jose, CA, pp.173-187, 1993.
- [4] J. Z. Wang, J. Li and G. Wiederhold, "SIMPLicity: Semantics-Sensitive Integrated Matching for Picture Libraries," IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol.23, No.9, September 2001.
- [5] G. Pass, R. Zabith, "Comparing images using joint histograms," Multimedia Systems, Vol.7, pp.234-240, 1999.
- [6] S. J. Eric, D. D. Tony, and S. H. David, "Wavelets fot computer graphics: A primer, part 1," IEEE, Computer Graphics and Applications, Vol.15 No.3, pp.76-84, 1995.
- [7] N.Cristianini, J.Shawe-Taylor 著, 大北 剛 訳, "サポートベクターマシン入門," 共立出版, 2005.